

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Primož Kocuvan

**Zaznavanje srčnega šuma v
fonokardiogramih**

DIPLOMSKO DELO

VISOKOŠOLSKI STROKOVNI ŠTUDIJSKI PROGRAM PRVE
STOPNJE RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: prof. dr. Neža Mramor Kosta

SOMENTOR: viš. pred. dr. Robert Rozman

Ljubljana 2015

Rezultati diplomskega dela so intelektualna lastnina avtorja in Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavljanje ali izkoriščanje rezultatov diplomskega dela je potrebno pisno soglasje avtorja, Fakultete za računalništvo in informatiko ter mentorja.

Besedilo je oblikovano z urejevalnikom besedil \LaTeX .

Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Tematika naloge:

Namen diplomskega dela je izgradnja modela za avtomatično razpoznavanje prisotnosti srčnega šuma v signalih, pridobljenih iz elektronskega stetoskopa. Razviti model bi lahko bil v pomoč zdravnikom pri diagnosticiranju bolezni srčnih zaklopk.

V diplomskem delu preučite metode za analizo zvočnih signalov, ki so primerne za obdelavo signala, pridobljenega iz elektronskega stetoskopa. Raziščite možnosti za razpoznavanje prisotnosti srčnega šuma v signalih in izberite primeren postopek za pridobitev značilk, ki najboljše opisujejo prisotnost šuma v fonokardiogramu. S pomočjo metod strojnega učenja, ki so na voljo v okolju Orange, zgradite model za klasifikacijo fonokardiogramov. Za izgradnjo modela uporabite javno dostopne označene realne podatke. Ocenite klasičnjo točnost razvitega modela in jo primerjajte z obstoječimi metodami.

IZJAVA O AVTORSTVU DIPLOMSKEGA DELA

Spodaj podpisani Primož Kocuvan, z vpisno številko **63100046**, sem avtor diplomskega dela z naslovom:

Zaznavanje srčnega šuma v fonokardiogramih

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelal samostojno pod mentorstvom prof. dr. Neže Mramor Kosta in somentorstvom viš. pred. dr. Roberta Rozmana,
- so elektronska oblika diplomskega dela, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko diplomskega dela,
- soglašam z javno objavo elektronske oblike diplomskega dela na svetovnem spletu preko univerzitetnega spletnega arhiva.

V Ljubljani, dne 10.julij 2015

Podpis avtorja:

Zahvaljujem se vsem specialistom kardiologom s katerimi sem sodeloval ter odseku za računalniške sisteme na Inštitutu Jožefa Stefana, ki so mi omogočili raziskovalno delo na področju medicine. Zahvaljujem se tudi mentorici in somentorju za usmerjanje in pomoč pri pisanju diplomskega dela.

Kazalo

Povzetek

Abstract

1	Uvod	1
1.1	Splošni uvod in namen	1
1.2	Sestava dela	2
2	Kratek uvod o delovanju srca	3
2.1	Kronološki pregled razvoja stetoskopa	3
2.2	Fiziologija srca in delovanje	4
2.3	Obravnavane diagnoze v kardiologiji	6
3	Opis podatkov	9
3.1	Opis podatkovne baze	9
4	Uporabljene metode	13
4.1	Priprava podatkov	13
4.2	Metode digitalnega procesiranja signalov	15
4.2.1	Naravne omejitve	15
4.2.2	Normalizacija fonokardiogramskega signala	16
4.2.3	Diskretna Fourierjeva transformacija (DFT)	18
4.2.4	Diskretna kosinusna transformacija (DCT)	19
4.2.5	Valčne funkcije	20
4.2.6	Melodični frekvenčni kepstralni koeficienti (MFCC)	22

KAZALO

4.2.7	Postopek izračuna MFCC značilnk	23
4.2.8	Adaptivni dinamični algoritem za določanje srčnih to- nov na ovojnici	23
4.3	Metode strojnega učenja	25
4.3.1	Umetne nevronske mreže	25
4.3.2	Naivni Bayesov klasifikator	26
4.3.3	Metoda podpornih vektorjev	27
4.3.4	Metoda k najbližjih sosedov	29
4.4	Podroben opis celotnega postopka	29
5	Evalvacija rezultatov	35
5.1	Mere za oceno uspešnosti ML	35
5.2	Rezultati	36
5.2.1	Rezultati nadzorovanega učenja z 13 MFCC	37
5.2.2	Rezultati nadzorovanega učenja z 200 MFCC	41
6	Zaključek in nadaljnje delo	45
7	Dodatek	47

Seznam uporabljenih kratic

kratica	angleško	slovensko
CA	classification accuracy	klasifikacijska točnost
ROC	receiver operating characteristic	krivulja ROC
K-NN	K nearest neighbour	K najbližjih sosedov
SVM	support vector machine	metoda podpornih vektorjev
WAV	Waveform audio format	Valčni zvokovni format
Hz	Unit Hertz	Kratica za enoto herz
MFCC	mel frequency cepstral coefficients	melodični frekvenčni kepsralni koeficienti
ML	Machine learning	Strojno učenje
FT	Fourier transform	Fourierjeva transformacija
CT	Cosine transform	Kosinusna transformacija
DFT	Discrete Fourier transform	Diskretna Fourierjeva transformacija
S1	First heart sound	Prvi srčni ton
S2	Second heart sound	Drugi srčni ton
S3	Third heart sound	Tretji srčni ton
S4	Fourth heart sound	Četrty srčni ton

Povzetek

Srčna avskultacija je najstarejša neinvazivna metoda za odkrivanje bolezni srčnih zaklopk. V diplomu smo se osredotočili na analizo fonokardiogramov s pomočjo metod digitalnega procesiranja signalov ter metod umetne inteligence za klasifikacijo. Signal pridobljen iz elektronskega stetoskopa smo razdelili v segmente, kjer en segment ustreza enemu kardialnemu ciklu. Nad segmentom smo izračunali MFCC značilke, katere smo uporabili kot vhod algoritmom strojnega učenja v programskem sistemu Orange. Ciljni klasifikacijski razred je stanje pacienta. Ločevali smo med fonokardiogrami s prisotnim šumom in brez. Najboljšo klasifikacijsko točnost smo dosegli z naivnim Bayesovim klasifikatorjem. Dosegli smo 92,4 % točnost pri pričakovani točnosti večinskega klasifikatorja 75,2 %. Dosegli smo 76,9 % senzitivnost in 95,4 % specifičnost, prav tako z naivnim Bayesovim klasifikatorjem. Po našem mnenju bi lahko bil tak sistem pomoč zdravnikom pri diagnosticiranju bolezni srčnih zaklopk. V teoretičnem delu diplome smo na kratko opisali algoritme, katere smo uporabljali ter kakšne so naravne omejitve pri delu s procesiranjem signalov.

Ključne besede: avskultatorni fenomeni, bolezni srčnih zaklopk, elektronski stetoskop, MFCC, digitalno procesiranje signalov.

Abstract

Heart auscultation is one of the oldest non-invasive method for detection valvular heart disease. In thesis we have focused on the analysis of phonocardiograms with digital signal processing methods and methods of artificial intelligence for classification. We have divided the signal obtained from electronic stethoscope in to segments where one of the segment corresponds to one cardiac cycle. After that we calculate MFCC features on one of the segments. The features serve as an input to machine learning algorithms in system Orange. Target classification class is the condition of a patient. We have distinguish the phonocardiograms with a heart murmur and without it. The best classification accuracy that we achieved is with naive Bayes classifier of 92.4 %. The expected accuracy of majority class was 75.2 %. The best achieved sensitivity and specificity was 76.9 % and 95.4 % respectively, also with naive Bayes classifier. In our opinion such system could be used by physicians to help diagnose heart valve diseases. In theoretical part of the thesis we have described algorithms that we used and what are the limitations of processing a signal.

Keywords: auscultation phenomena, heart valve disease, electronic stethoscope, MFCC, digital signal processing.

Poglavje 1

Uvod

1.1 Splošni uvod in namen

V pričujočem diplomskem delu bomo podrobno obravnavali fonokardiograme, akustične posnetke bitja srca, ki jih zdravniki pridobijo s pomočjo neinvazivne metode osluškovanja šumom. Ta neinvazivna tehnika se imenuje kardialna avskultacija. Napredek v elektroniki omogoča računalniško karakterizacijo posnetkov. Cilj diplomskega dela je s pomočjo metod za analizo signalov pridobiti značilke signala, ki jih lahko uporabimo za klasifikacijo primerov na normalne ali takšne s prisotnim srčnim šumom. Pomembno je, da se postopki za iskanje bolezni srčnih zaklopk, na podlagi avskultatornega posnetka srca avtomatizirajo, saj s tem bolj objektivno ocenimo stanje pacienta.

Prav tako se bomo v diplomskem posvetili raziskavi in analizi različnih metod za ločevanje oziroma dekompozicijo celotnega avskultatornega signala v okvirje, tako da bomo vsak okvir opisali z vektorjem značilk, kot je v navadi pri razpoznavi govora. Raziskali bomo nabor najbolj značilnih metod s področja digitalnega procesiranja signalov, kot so melodični frekvenčni kepralni koeficienti (v nadaljevanju MFCC), valčne transformacije in Fourierjeva transformacija ter različne variacije Fourierjeve transformacije. Za klasifikacijo ter povezovanje vektorjev značilk s patološkimi stanji pacientov

pa bomo uporabili nevronske mreže kot začetni izbor. Poskusili pa bomo tudi z metodo k-najbližjih sosedov, metodo podpornih vektorjev in z naivnim Bayesovim klasifikatorjem.

Sledi natančnejši opis dela. Vizualno bomo primerjali močnostne spektre posnetkov s prisotnim šumom in brez ter tako ugotovili, katere frekvenčne pasove zavzamejo fonokardiogrami. S poznavanjem tega dejstva bomo s pomočjo valčne dekompozicije z valčkom Coiflet 3 [6] razdelili celoten surovi signal na posamezne frekvenčne komponente. Nato ga bomo rekonstruirali na isti stopnji. S tem korakom bomo odstranili manj izrazite frekvenčne oscilacije. Nato bomo uporabili Morletovo valčno funkcijo za zvezno valčno transformacijo ter tako konstruirali ovojnico. Napisali bomo svojevrsten adaptivni dinamični algoritem, s pomočjo katerega bomo razdelili signal na intervale. Iz razdeljenih intervalov bomo vzeli samo prvega ter ga uporabili kot vhod za izračun koeficientov MFCC. Ciljni razred je razlikovati signale s prisotnim šumom, ki je lahko fiziološki ali patološki in signal brez njega. Torej signale, ki so jih specialisti kardiologije označili kot *MURMUR* in *NORMAL*. Rezultate bomo primerjali z že znanimi ugotovitvami na tem področju.

1.2 Sestava dela

Delo je sestavljeno iz štirih poglavij, vključno z uvodom. Deli se na teoretični del, ki zajema vse do vključno tretjega poglavja. V zadnjih treh poglavjih je predstavljen postopek in rezultati. Na začetku podamo kratek uvod, kjer je opisano delovanje srca ter osnove, ki jih potrebujemo za razumevanje celotnega dela. Osnovni korak pri avtomatskem opisovanju podatkov je poznavanje področja. Nato sledi opis podatkovne baze ter opis metod, ki smo jih uporabili za procesiranje podatkov. Podamo tudi smiselni kratek uvod v strojno učenje, ter na koncu dela ovrednotimo rezultate ter opišemo smernice za nadaljnji razvoj. Delo je strukturirano na takšen način, da ni potrebno imeti nikakršnega predznanja, saj je vse opisano in razloženo v njem samem.

Poglavje 2

Kratek uvod o delovanju srca

V nadaljevanju bomo spoznali osnovno delovanje kardiovaskularnega sistema v človeku ter opredelili nekatere pogostejše diagnoze srčnih zaklopk. Delno se bomo poglobili v fiziologijo srca in ugotovili, kako pomemben je ta muskulatorni organ. Organ, nadzira živčni sistem in njegovo delovanje je odvisno od tega, katera vrsta živčnega sistema je trenutno prevladujoča. Poglavje začnemo s kratkim pregledom razvoja stetoskopa, osnovnega pripomočka, s katerim si zdravniki pomagajo pri parcialnem diagnosticiranju. Končno diagnozo zdravniki oziroma specialisti kardiologije postavijo z bolj sofisticiranimi preiskavami, na primer ultrazvočno preiskavo srca.

2.1 Kronološki pregled razvoja stetoskopa

Avskultacija je ena izmed najstarejših metod za diagnosticiranje respiratornih bolezni in patoloških srčnih fenomenov. Sam začetek poslušanja delovanj notranjih organov je začel raziskovati antični grški zdravnik Hipokrat. Vendar je bil poglobljen napredek dosežen šele leta 1816 z izumom stetoskopa, ko je francoski zdravnik Rene Laennec [8] med pregledom slišal dodatne šume s kosom zvitega papirja. Pozneje je sam izdelal cev iz lesa, s katero je pregledoval paciente. Ime stetoskop izhaja iz grščine, kjer *stethos* pomeni prsni koš in *scopos* raziskati. Do začetka 20. stoletja so bili stetoskopi izdelani


mono slušno, pozneje pa so enojno cev nadomestili z dvema, za vsako uho eno. Stetoskop je sestavljen iz dela, ki se imenuje glava ter slušni del. [9] Glavo zdravniki prislonijo na toraks (prsni koš) za npr. avskultacijo srca. Glava vsebuje membrano, ki niha longitudinalno in s tem se generira zvok. Z rapidnim razvojem tehnologije so se okoli leta 1980 pojavili elektronski stetoskopi. Ena od aplikacij modernega stetoskopa je spremljanje srčnega utripa še nerojenega otroka tako, da ovijejo trak okoli trebuha (abdomen). Takšna metoda se imenuje eksterni monitoring. V prihodnosti naj bi se razvijali inteligentni elektronski stetoskopi za domačo uporabo. Možen je tudi razvoj ekspertnega sistema, kar je tudi namen tega diplomskega dela, da se postopki za postavljanje diagnoze avtomatizirajo.

2.2 Fiziologija srca in delovanje

Srce je mišični organ sestavljen iz leve in desne srčne mišice. Naloga obeh je, da stiskata kri vsaka v svoj obtok. Ločimo veliki in mali krvni obtok. Mali krvni obtok sestavljajo vene in desna srčna mišica, ki se deli na preddvor in prekat. Po venah dobiva srce kri, ki vsebuje odpadne snovi ter ogljikov dioksid. Dobljena kri se skladišči v desnem preddvoru, nato preide v desni prekat iz katerega srce požene kri v pljučne arterije. Srčne zaklopke preprečujejo, da bi se kri vračala nazaj po isti poti. Kri se obogati s kisikom v pljučih in odda ogljikov dioksid. Nalogo tega imajo posebna krvna telesca imenovana eritrociti, katera prejmejo vdihnjen kisik in oddajo ogljikov dioksid, katerega izdihnemo. Po slednjem procesu preide kri v desno srčno mišico, ki stisne kri v veliki krvni obtok. Veliki krvni obtok, ki se tudi imenuje sistemski krvni obtok, razvede kri v vse celice v sistemu tudi do najbolj oddaljene celice preko perifernih arterij in aorte.

Kardialni cikel je sestavljen iz sistole, to je interval, na katerem se srce skrči in diastole, kjer se srce raztegne. Sistola je interval srčnega cikla, ki je krajši

od diastole. Prvi srčni ton S1 se pojavi na začetku sistole. Srčni ton je karakteristika bitje srca in je podrobneje razložen v nadaljevanju. Za njega je značilno, da obsega interval frekvenčnih vrednosti med 10 in 200 Hz, ter da ima amplitudni odziv višji kot drugi kardialni fenomeni [9]. Drugi srčni ton, katerega označujejo v medicini kot S2, se pojavi na začetku diastole in vsebuje dve višji frekvenčni komponenti. Če ga primerjamo s S1 dosega S2 višje frekvence.




Slika 2.1: Fonokardiogram, kjer je označen en kardialni cikel

Srce ima štiri srčne zaklopke:

- trikuspidalna zaklopka,
- zaklopka pljučne arterije,
- aortna zaklopka,
- mitralna zaklopka.

V sistoličnem intervalu srčnega ritma se prekata skrčita ter trikuspidalna in mitralna zaklopka se zapreta, kar slišimo s stetoskopom kot srčni ton S1. V drugem delu cikla srca imenovanem diastola se zaklopka pljučne arterije in zaklopka aorte zapreta, kar slišimo kot srčni ton S2. Ko sta dve zaklopki




Slika 2.2: Prerez srca [15]

zaprti, sta drugi dve odprti. Hibe so možne, ko je katera od zaklopk zožena ali se ne zapre zadosti. Če je zožena, mora srčna mišica proizvesti zadosten večji pritisk kot običajno, da lahko kri požene po telesu. V nasprotnem primeru, če se ne zapre zadosti, pa nekaj krvi steče v nasprotni smeri. Vzrokov, da se poškoduje delovanje srčnih zaklopk, je več. Posledice so lahko tudi zaradi stresnega življenja ali pa so prirojene.

2.3 Obravnavane diagnoze v kardiologiji

Slika 2.3 prikazuje sintetični normalni signal. Opazimo lahko, da šuma ni prisotna niti na sistoli niti na diastoli. Na diastoli sta prisotna z nizko amplituda srčna tona S3 in S4. Pojav omenjenih srčnih tonov se prepleta s fiziološkimi in patološkimi dejavniki. Torej lahko se pojavita pri zdravem pacientu ali bolnem. Zato v diplomskem delu ne bomo obravnavali dodatna srčna tona, saj ne moremo določiti razlik z algoritmi digitalnega procesiranja signalov.




Slika 2.3: Primer normalnega sintetičnega signala [14]

Nekaj pogostejših bolezni srčnih zaklopk, kjer se kot eden od simptomov pojavlja srčni šum so:

- aortna stenoza,
- aortna insuficienca,
- mitralna stenoza,
- mitralna insuficienca.


Izraz stenoza pomeni zoženje krvnih žil. Posledica tega je nezadostna oskrbljenost krvi skozi koronarne arterije. Tako se poveča možnost za nenadno smrt zaradi zastoja srca. Na sintetični sliki 2.4 lahko opazimo na sistoli šum, ki je tipa crescendo-decrescendo, kar pomeni, da je na začetku manjša amplituda, nato doseže vrh, na koncu se pa spet zniža. Šum se na sistoli razteza čez celoten interval. Signal je periodičen in sistolično naključen. Sistolično naključen pomeni, da je prisoten šum na sistoličnem intervalu srčnega ritma, ki ni matematično opisljiv. Na diastoli ni prisotnega šuma in je idealno konstanten, kar pa ne velja za signale snemane v realnih pogojih.

Izraz insuficienca pomeni, da gre za nezadostno zapiranje zaklopke, kar povzroča tok krvi v nasprotno smer. Na sintetični sliki 2.5 opazimo, da je sedaj šum prisoten na diastoli in je tipa decrescendo, kar pomeni, da amplituda pada. Šum se na diastoli razteza čez celoten interval. Signal je diastolično naključen, kar pomeni, da šum na diastoli ni matematično opisljiv.



Slika 2.4: Primer šumnega sintetičnega signala aortne stenoze [14]

Na sistoli ni prisotnega šuma. Iz slik se tudi opazi, da je sistoličen interval krajši kot diastolični, kar nam pride prav pozneje pri določanju intervalov srčnega ritma.



Slika 2.5: Primer šumnega sintetičnega signala aortne insuficience [14]

Poglavje 3

Opis podatkov


V tem poglavju bomo na kratko opisali bazo podatkov ter predprocesiranje signala. Predprocesiranje je pomemben korak pri pripravi podatkov. Pri predprocesiranju ponavadi odstranimo šum in napake na podatkih, normaliziramo signal ter s filtri pridobimo intervale za nas pomembnih podatkov. Uporabili smo prosto dostopno spletno bazo posnetkov fonokardiograma [7].

3.1 Opis podatkovne baze


Podatkovna baza, ki je vir fonokardiogramov, vsebuje skupaj 264 posnetkov razdeljenih v dva razreda. Je neuravnotežena, saj je 200 posnetkov označenih kot Normal in 64 je označenih kot Murmur. Deli se na podatkovno množico A in jo sestavljajo posnetki posneti z aplikacijo za iPhone ter podatkovno množico B, ki je sestavljena iz kliničnih posnetkov posnetih z elektronskim stetoskopom DigiScope. Za namene diplomske naloge smo uporabili samo množico B. Ciljni atribut je bolezensko stanje in je lahko:

- Normalno: Slika 3.1
- Šum: Slika 3.2

Slika 3.1 prikazuje fonokardiogram pacienta, ki je označen kot Normal. Na sliki so konice, ki predstavljajo srčne tone S1 in S2. Sistola je interval cikla,



Slika 3.1: Naravni normalni signal



Slika 3.2: Naravni signal s šumom

ki sledi srčnemu tonu S1 in se loči s srčnim tonom S2. Temu sledi diastola. Nobeden od obeh intervalov nima prisotnega šuma. Slika 3.2 prikazuje fonokardiogram pacienta, kjer se pa opazi, da je šum prisoten tako na sistoli kot na diastoli. Ta fonokardiogram je označen kot šumni (angl. Murmur).

Vsi posnetki so vzorčeni s frekvenco 4kHz, kar pomeni, da posnetek dolg 1 sekundo sestavlja 4000 vzorcev. Posnetki so variabilne dolžine, dolgi med


1 in 30 sekundami. Pridobljeni so na pacientih otrok in odraslih v različnem stanju. Zato je srčni utrip nekaterih pacientov višji od 140. Za večino pacientov v bazi pa velja, da se nahaja med 60 in 100 utripi na minuto [7]. Teorem v teoriji informacij pravi: *Zvezen signal je lahko pravilno vzorčen, če in samo če ne vsebuje frekvenčnih komponent nad eno polovico frekvence vzorčenja* [4]. Za vse avskultatorne fenomene, ne glede na to, kako so pridobljeni, velja, da se srčni toni nahajajo v v frekvenčnem območju med 10 in približno 190 Hz [7]. Šumi so višje frekvence v območju med 276 in 551 Hz [6]. Zato če se vrnemo na teorem, so posnetki vzorčeni s pravilno frekvenco in bi jo lahko zaradi hitrosti procesiranja podatkov prevzorčili na nižjo frekvenco, tako kot so to naredili raziskovalci v članku [6]. V diplomskem delu tega nismo naredili, saj je hitrost obdelave podatkov nepomembna za nas. Vsi posnetki so shranjeni v zvokovni datoteki WAV.

Poglavje 4

Uporabljene metode

4.1 Priprava podatkov

Na podlagi članka [6] smo se odločili za izbiro tipa valčne funkcije, ki se imenuje Coiflet 3 (slika 4.1). Coiflet valčne funkcije so skoraj simetrične in imajo več koeficientov v nižji in v višji stopnji kot preprostejše valčne funkcije npr. Haar.



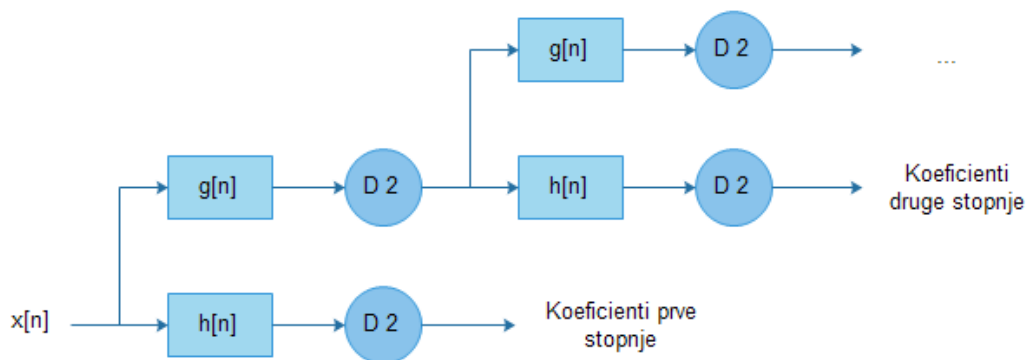
Slika 4.1: Coiflet 3

Coiflet valčno funkcijo bomo tudi uporabili pri separaciji šuma od nor-

malnih komponent srčnega ritma. V koraku predprocesiranja osnovni surovi signal se razdeli na naslednje komponente [6]:

- detajli prve stopnje (d1): 551 Hz - 1102 Hz,
- detajli druge stopnje (d2): 276 Hz - 551 Hz,
- detajli tretje stopnje (d3): 138 Hz - 276 Hz,
- aproksimacija tretje stopnje (a3): 0 Hz - 138 Hz.

Slika 4.2 prikazuje drevo, ki se imenuje banka filtrov (angl. filter bank). Banka filtrov je skupina oziroma množica različnih filtrov. Množica filtrov je sestavljena iz nizko-prepustnih in visoko-prepustnih filtrov. Omogoča spektralno dekompozicijo originalnega signala v več komponent ter spektralno kompozicijo [10]. Kar pomeni, da lahko razgradimo signal na manjše komponente ali pa ga zopet združimo iz različnih filtrov. Tukaj je $x[n]$ osnovni signal, izraz v krogu označen kot $D2$ pa pomeni znižanje frekvence vzorčenja za faktor 2 (angl. downsampling). Na sliki je prikana le dvostopenjska dekompozicija. Koeficienti prve stopnje na sliki ustrezajo detajlom prve stopnje in tako naprej vse do zadnje stopnje pri kateri ni več nadaljnje delitve. Zadnje stopenjski koeficienti ustrezajo aproksimacijskim.



Slika 4.2: Banka filtrov


4.2 Metode digitalnega procesiranja signalov

Transformacija osnovnega signala je preslikava, ki signal preoblikuje, pri čemer dobimo značilne lastnosti tega signala. Osnovni surovi signal razstavimo v manjše kompaktnejše elemente, ki sestavljajo nov signal, iz katerega lahko sklepamo o sami naravi in sestavi surovega signala. Splošno delimo signale na stacionarne in nestacionarne. Stacionarni se periodično ponavljajo, njihov frekvenčni spekter se s časom ne spreminja. V bioloških merjenjih, kot je elektroencefalografija, elektromiografija ter elektrokardiografija, pa imamo opravka z nestacionarnimi signali. Zato je pomembno, da najdemo primerno transformacijo za obdelavo surovega signala. Za začetek lahko omenimo najbolj znano Fourierjevo transformacijo, ki jo uporabljajo v spektralni analizi, ali pa kot del večje metode, kar je opisano v podpoglavju 4.2.6. Ta slika signal odvisen od časovne spremenljivke na abscisni osi v isti signal, ki se izraža s frekvencami ki v njem nastopijo. Vendar ima Fourierjeva transformacija slabo lastnost, da dobimo le frekvence, informacije o času, kdaj se je določena frekvenca pojavila v osnovnem surovem signalu pa ni. V diplomski nalogi podrobneje obravnavamo bioakustične signale, za katere je zelo pomembna lastnost tudi čas, v katerem se določena frekvenca pojavi.

4.2.1 Naravne omejitve

Za signal, enako kot je to vidno v drugih pojavih v naravi, veljajo tako imenovane naravne omejitve, ki nas omejujejo pri hkratnem določanju frekvence in časa. Slika 4.3 prikazuje, kako interpretiramo frekvenčne in časovne resolucije [3]. Na sliki imamo dve osi, ena označuje čas in druga frekvence. Pri nizkih frekvencah je višina stolpiča, (kar je na sliki vidno kot dolg pas) majhna, kar pomeni boljšo frekvenčno resolucijo, vendar je dolžina stolpiča velika, kar pomeni slabo časovno resolucijo. V obratni smeri, kjer je frekvenca visoka, lahko lažje določimo časovno komponento, frekvenco pa s težavo. Tukaj nastane dilema oziroma iščemo kompromis med frekvenco in časom (angl. trade-off). Bolj natančno ko določimo čas, manj natančno poznamo njegovo

frekvenco. To je pasovna širina v tem časovnem intervalu in obratno.




Slika 4.3: Časovna-frekvenčna resolucija

4.2.2 Normalizacija fonokardiogramskega signala


Normalizacija pomeni prilagajanje oziroma skaliranje podatkov, tako da se podatki nahajajo v določenem obsegu oziroma intervalu vrednosti. Gre za kreiranje poravnanih podatkov, t.i. normaliziranih vrednosti in omogoča, da lahko podatke med seboj primerjamo, tudi če jih pridobimo iz različnih podatkovnih baz. Normalizacija je proces, s katerim reduciramo meritve na neko vnaprej definirano merilo oziroma obseg nevtralnih vrednosti [11]. Izraz nevtralne vrednosti pomeni, da ne pride do nesoglasij med podatki. V našem primeru smo normalizirali avskultatorne posnetke na interval med -1 in 1 z naslednjo enačbo:

$$x_{norm}(t) = \frac{x(t)}{\max(|x(t)|)} \quad (4.1)$$

kjer je $x(t)$ signal, max je funkcija, ki vrne maksimum v vektorskem signalu. Učinek normalizacije signala je prikazan na slikah 4.4 in 4.5.



Slika 4.4: Fonokardiogram pred normalizacijo



Slika 4.5: Fonokardiogram po normalizaciji

4.2.3 Diskretna Fourierjeva transformacija (DFT)

V uvodu smo omenili, da Fourierjeva transformacija (FT) ni primerna za analizo, saj ne dobimo vrnjene časovne komponente. V splošnem lahko izračunamo Fourierjevo transformacijo za celoten signal, vendar se potem ne loči na katerem segmentu signala je prisoten šum. Sicer poznamo še STFT (Short Time Fourier Transform), pri kateri je dolžina okvirja fiksna. Tako ne bi razpoznali nekaj vrst bolezni srčnih zaklopk. Je pa ena izmed metod za izračun melodičnih frekvenčnih kepstralnih koeficientov in nima vpliva na končni rezultat.

Na Fourierjevo transformacijo lahko gledamo kot koreliranost signala s periodičnim kompleksnim signalom. Korelacija je vsota produktov posameznih vrednosti obeh signalov. Če sta trenutni vrednosti pozitivni ali, če sta obe negativni, potem prispevata pozitivno vrednost končni vsoti. Če in samo če sta predznaka različna, pa prispevata negativno vrednost končni vsoti. Korelacija med signaloma je največja, ko dobimo nenegativno visoko vrednost. Če dobimo vrednost blizu nič ali manjšo, potem pravimo, da sta signala nekorelirana.

Matematično zapišemo korelacijo z:

$$\sum_{i=1}^n x(i)y(i) \quad (4.2)$$

Diskretna Fourierjeva transformacija je podana s enačbo:


$$X(k) = \sum_{n=1}^N x(n)e^{-2\pi i kn/N} \quad (4.3)$$

Torej računamo korelacijo med našim signalom in kompleksnim periodičnim

signalom s periodo N . Sam izraz lahko zapišemo z slednjo enačbo:

$$X(k) = \sum_{n=1}^N x(n) \cos\left(\frac{2\pi kn}{N}\right) + i \sum_{n=1}^N x(n) \sin\left(\frac{2\pi kn}{N}\right), \quad (4.4)$$

Slika 4.6 in slika 4.7 prikazujeta graf opravljene Fourierjeve transformacije nad primerom signala iz elektronskega stetoskopa s šumom in brez njega. Na sliki prikazujemo absolutni amplitudni odziv in ne njene kompleksne vrednosti. Vidimo lahko, da se šum nahaja v frekvenčnem pasu med 150 Hz in 1000 Hz. Najbolj izrazit, torej največjo višino dosega pri frekvenci 200 Hz. Medtem ko signal, ki je označen kot Normal, vsebuje le frekvence, ki so manjše od 100 Hz.




Slika 4.6: DFT normalnega fonokardiograma

4.2.4 Diskretna kosinusna transformacija (DCT)

Slednja transformacija je podobna Fourierjevi, vendar z razlikami:

- diskretna kosinusna transformacija ni kompleksna,



Slika 4.7: DFT fonokardiograma s šumom

- uporablja se kot algoritem za kompresiranje podatkov,
- računsko učinkovitejša in manjša časovna zahtevnost kot Fourierjeva transformacija.

Diskretna kosinusna transformacija je definirana z naslednjo enačbo:


$$X_k = \sum_{n=0}^{N-1} x_n \cos \left[\frac{\pi}{N} \left(n + \frac{1}{2} \right) k \right] \quad (4.5)$$

Tako kot pri diskretni Fourierjevi transformaciji, se tudi ta računa s končnimi vsotami, nad končnim zaporedjem števil, ki predstavljajo signal. Rezultat je končno zaporedje. Iz enačbe se vidi, da je kosinusna transformacija samo izpeljanka Fourierjeve, pri čemer ne upoštevamo kompleksnega sinusnega dela. Tako le-ta postane realna. Ujema se s simetričnimi sodimi signali. V primeru, da ni sodi signal, ga transformacija razširi v sodega.

4.2.5 Valčne funkcije

Valčne funkcije so posebne družine funkcij, katerim je skupno, da izhajajo iz ene same prototipne funkcije (angl. Mother wavelet). Pogosto se uporabljajo

v algoritmih za stiskanje podatkov, znani primer je kompresijski standard JP2, ki je nadomestil diskretno kosinusno transformacijo. Temeljna razlika med Fourierjevo transformacijo in valčnimi funkcijami je, da slednje vrnejo dodaten parameter in to je lokacija v času. Na sliki 4.8 je kompleksna Morletova valčna funkcija, s pomočjo katere v našem primeru zgradimo ovojnico signala.



Slika 4.8: Morletova valčna funkcija

Zvezna valčna transformacija signala $x(t)$ je podana z enačbo:

$$W(a, \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \psi\left(\frac{t - \tau}{a}\right) x(t) dt \quad (4.6)$$

kjer je τ translacijski parameter. Določa premik po časovni osi. Parameter a je skalirni faktor, ki določa razširitev signala ali kompresijo. Če je skalirni faktor večji od 1, to pomeni operacijo razširitve v nasprotnem primeru, če je manjši od 1 pa pomeni kompresijo. Funkciji ψ rečemo mati valčnih funkcij in se uporablja kot prototip za generacijo različnih variacij funkcij parametra τ in a . Ulomek $\frac{1}{\sqrt{a}}$ je normalizacijske narave, zato da ima rezultat enako

porazdeljeno energijo.

4.2.6 Melodični frekvenčni kepralni koeficienti (MFCC)

V začetku bomo razčlenili naslov. Mel je enota, ki izhaja iz besede melodija (angl. Melody). Če je vir zvoka oseba, je višina tona odvisna od karakterističnih lastnosti vokalnega trakta govorca. Besedo frekvenčno uporabljamo, zato ker se nanaša na frekvenčno analizo signala. Frekvenca je povezana s toni, ki sestavljajo kompleksnejše zvoke. Frekvenčna analiza je postopek, ki nam signal izrazi z vsoto elementarnih elementov (tonov) različnih frekvenc. Kepster (angl. cepstrum) je besedno obrnjeno spekter (angl. spectrum). Navezuje se na uporabo inverzne Fourierjeve transformacije v originalnem postopku. Za analizo in procesiranje zvoka je inverzna Fourierjeva transformacija nadomestila diskretna kosinusna transformacija, ime je pa ostalo enako.

Na koncu izračuna dobimo vektor, sestavljen iz koeficientov pri posameznih frekvencah v melodični lestvici. Metodo so začeli široko uporabljati v razpoznavi govora, pri identifikaciji govorca, in pri razlikovanju med spoloma v govoru. Zvočni signali katere dobimo oziroma so posneti z elektronskim stetoskopom, se konstantno spreminjajo. Vendar iz vidika okvirjev, ko celotni signal razdelimo v manjše skupine, kjer je vsak okvir dolg nekaj milisekund so spremembe v nihanju komaj vidne. V naslednjih korakih izračunamo spekter moči in za spekter moči označimo kateremu frekvenčnemu pasu pripada. Začetni frekvenčni pas je zelo ozek in zajema frekvence okoli ničle. S stopnjevanjem proti višjim frekvencam se frekvenčni pasovi razširijo. Rezultat logaritmiramo, saj naša percepcija sluha deluje na logaritemski skali. Ker se filtri, prekrivajo izračunamo diskretno kosinusno transformacijo, da znižamo dekoreliranost.


4.2.7 Postopek izračuna MFCC značilk

MFCC značilke bomo v našem primeru uporabili za frekvenčno analizo signala. Postopek izračuna MFCC značilk je sestavljen iz šestih korakov [16]


1. Signal razdelimo v manjše okvirje.
2. Za vsak okvir izračunamo Fourierjevo transformiranko.
3. Za dobljeni spekter izračunamo mel banko filtrov in seštejemo energijo v vsakem filtru.
4. Logaritmiramo posamezne energije.
5. Izračunamo diskretno kosinusno transformacijo za vsako energijo.
6. Uporabimo samo nekaj začetnih koeficientov, ostale zavržemo.

4.2.8 Adaptivni dinamični algoritem za določanje srčnih tonov na ovojnici

Pri izračunu ovojnice signala je potrebno določiti srčne tone, zato da se loči en srčni cikel. Ideja algoritma je v tem, da bo interval, ki na primer ustreza sistoli, statistično enake absolutne dolžine kot predhodna sistola, saj se frekvenca srčnega utripa ne spremeni v trenutku. Za spremembo frekvence srčnega utripa je potreben čas, fonokardiogrami pa so dolgi nekaj sekund. V resnici trenutna sistola in neposredna prejšnja ne bosta popolnoma enake absolutne dolžine. Razlikovala se bosta v manjšem številu vzorcev. Zato je predhodno glede na bazo posnetkov potrebno nastaviti nek prag, ki določa razliko. V našem problemu smo uporabili prag nekaj milisekund. Za nadaljevanje tega dela bi bilo potrebno imeti dovolj veliko množico in izmeriti povprečno razliko za različne frekvence bitja srca. Možno je, da se razlika porazdeljuje po kakšni znani statistični porazdelitvi, vendar tega še ne vemo.



Slika 4.9: Primer ovojnice signala in določitev srčnih tonov z uporabo dinamičnega algoritma



Slika 4.10: Primer ovojnice signala in določitev srčnih tonov brez uporabe dinamičnega algoritma


Kot lahko opazimo iz slik grafov ovojnice 4.9, 4.10, lahko rečemo, da adaptivni dinamični algoritem izboljša določanje praga, ki ločuje srčne tone od šuma. Ko določimo maksimume, dobimo lokacije srčnih tonov v originalnem posnetku, kot to prikazuje slika 4.15. V zadnjem koraku celotnega algoritma smo izračunali MFCC nad prvim kardialnim ciklom označenega signala.

4.3 Metode strojnega učenja

Z metodami strojnega učenja želimo računalnik naučiti razlikovati med razredi. Imamo dva razreda: signal s prisotnim šumom in signal brez šuma. V našem primeru imamo več končno mnogo MFCC značilk, za katere ne poznamo natančnega postopka, ki bi klasificiral oziroma razlikoval med značilkami, ki pripadajo razredu Normal ali razredu Murmur. Zato smo uporabili za klasifikacijo metodo umetne nevronske mreže, prav tako pa smo za primerjavo uporabili metodo k najbližjih sosedov, metodo podpornih vektorjev in naivni Bayesov klasifikator.

4.3.1 Umetne nevronske mreže

Obstaja veliko računskih metod, ki so navdahnjene s procesi v naravi kot so evolucijsko računanje, imunski sistem in seveda nevronske mreže, ki se uporabljajo v umetni inteligenci. Umetne nevronske mreže so preprost model bioloških možganov živih bitij. Biološki možgani so sestavljeni iz živčnih celic imenovani nevroni, ki so med seboj povezani s sinapsami. Delujejo po preprostem principu prenašanja akcijskega potenciala preko nevitov, ki so izrastki iz telesa živčne celice. Umetni nevron je preprost model biološkega in je določen z vhodnimi povezavami in pripadajočimi utežmi ter z eno izhodno povezavo vezano na drugi nevron. Nevroni so t.i. preproste procesne enote. Umetne nevronske mreže ločimo po različnih topologijah, pravilih učenja in namenu. Za namene učenja smo v našem algoritmu uporabili večnivojski perceptron.



Slika 4.11: Shema biološkega nevrona


Slika 4.11 prikazuje biološki nevron, ki je sestavljen iz some, telesa celice in izrastkov iz celice imenovani dendriti. Najdaljši izrastek se imenuje akson, in njegov konec se veže na sinapso drugega nevrona. Nevroni v živčnem sistemu človeka in drugih podobnih živih bitji so povezani nezaporedno. Pri klasificiranju pa ponavadi uporabljamo nevrone povezane kaskadno. Signal potuje od vhodnih nevronov preko skritih nivojev v izhod. Slika 4.12 prikazuje umetni nevron, ki je osnovna enota celotne mreže. Vsebuje vhode in uteži, katere indeksno množimo in jih seštejemo. Na koncu dobimo skalarno vrednost, ki jo uporabimo kot argument za pragovno funkcijo. Za pragovno funkcijo se največkrat uporabi sigmoidno funkcijo. Sigmoidna funkcija je definirana z naslednjo enačbo:

$$S(x) = \frac{1}{1 + e^{-\alpha x}} \quad (4.7)$$

Oblika funkcije nas spominja na obliko črke S. Slika na desni predstavlja asimptotično obliko sigmoidne funkcije.

4.3.2 Naivni Bayesov klasifikator

Iz Bayesovskega obrazca sledi splošna struktura. Bayesovski model je preprost za izgradnjo, kar pride prav pri velikih podatkovnih bazah [12]. Največkrat se model uporablja v medicini, saj so simptomi oziroma bolezenski znaki linearno neodvisni med seboj. Njegova preprostost večkrat preseže učinkovitost



Slika 4.12: Shema umetnega nevrona

drugih bolj sofisticiranih metod, kot so nevronske mreže. Bayesovski model predpostavlja linearno neodvisnost med atributi.

$$P(r_k|V) = P(r_k) \prod_i^n \frac{P(r_k|v_i)}{P(r_k)} \quad (4.8)$$

V enačbi predstavlja $P(r_k)$ apriorno verjetnost razredov. $P(V)$ je apriorna verjetnost primera z atributnim opisom, V in $P(r_k|v_i)$ sta pogojna verjetnost posameznega primera r_k pri pogoju v_i . Naivni Bayesov klasifikator uporabimo tako, da primer klasificiramo glede na vrednost $P(r_k|V)$. Če je končna verjetnost manjša od določenega praga, spada v prvi razred sicer v drugi.

4.3.3 Metoda podpornih vektorjev

Metoda podpornih vektorjev se uporablja v nadzorovanem učenju, kjer so učni primeri označeni. Deluje tako kot za klasifikacijske probleme kot tudi za regresijske. Obstaja celotna družina SVM (Support Vector Machine), z različnimi jedrnimi funkcijami:

$$S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (4.9)$$

kjer so x objekti, ki pripadajo učni množici. Objekti so vektorji končne dolžine in realnih vrednosti.

$$x \in X \quad (4.10)$$

In y so znani binarni razredi.

$$y \in \{-1, 1\} \quad (4.11)$$


Tukaj lahko opazimo, da uporabljamo dva možna razreda označena kot -1 in $+1$. To je zaradi matematične narave, ki se skriva v ozadju. Lahko bi si tudi izbrali 1 in 0 , vendar bi potem morali spremeniti matematično izpeljavo. Ohranili bomo vrednosti takšne, kot so napisane v originalnem algoritmu. Definiran je za dvorazredni klasifikacijski problem, kar je priročno za naš problem. Je diskriminatna metoda. Izraz diskriminatno izhaja iz latinske besede *discriminar*, kar pomeni ločevanje. Loči med učnimi primeri v prostoru značilk s pomočjo ravnine, tako da so učni primeri, ki pripadajo različnim razredom, maksimalno oddaljeni od ravnine. Za lažjo predstavo prikazujemo problem v ravnini na sliki 4.13. Skoraj za vse klasifikacijske probleme velja, da so formalno definirani v višjih dimenzijah. Enačba 4.11 predstavlja eno hiperravnino. Vektor w kaže v smeri normale, b je bias in predstavlja odmik ravnine od koordinatnega izhodišča.

$$w^T x + b = 0 \quad (4.12)$$

Iz slike 4.13 lahko dokažemo, da je širina roba enaka $\frac{2}{\|w\|}$, kar pomeni, da je širina inverzno proporcionalna dolžini normale, kjer je w normalni vektor. Parametra w in b določimo tako, da maksimiziramo širino roba med vzporednima ravninama, ki ločita razrede.

Nekatere lastnosti SVM modela [17] so:

- izboljšana izvedba za realne probleme,
- računska učinkovitost oziroma nezahtevnost,
- robustnost v višjih dimenzijah,
- maksimizacija razdalje od roba do najbližjega učnega primera, kar preprečuje preveliko prileganje (overfitting).



Slika 4.13: Primer SVM

4.3.4 Metoda k najbližjih sosedov


Metoda K najbližjih sosedov (KNN) je eden izmed najpreprostejših algoritmov, ki se uporablja tako za klasifikacijo kot za regresijo. V prostor značilk se preslikajo vsi učni primeri. Algoritem si tako zapomni vse učne primere, ki jih pridobi kot točke v Evklidskem prostoru. Slaba lastnost algoritma je v tem, da porabi veliko pomnilniškega prostora, v primeru velike učne množice. Pri klasifikaciji novega učnega primera algoritem pogleda k (parameter k je ponavadi liho število, zato da se ML algoritem lahko odloči, v kateri razred bo klasificiral nov primer) najbližjih sosedov in na podlagi večinskega glasovanja se odloči za razred.

V našem primeru smo uporabili Evklidsko metriko 4.13 za določitev najbližjih sosedov.

$$\sum_i^k \sqrt{(x_i - y_i)^2} \quad (4.13)$$

4.4 Podroben opis celotnega postopka

Uporabili smo programski paket *MATLAB*, v katerem smo implementirali metode, ki se tičejo digitalnega procesiranja signalov. V njem smo uporabili



Slika 4.14: Primer klasifikacije z KNN

že vgrajene funkcije. Za vsakega pacienta smo prebrali digitalni signal iz elektronskega stetoskopa ter ga obdelali, tako da smo na koncu dobili le MFCC značilke. Slednje značilke smo zapisali v datoteko ločeno s tabulatorji. Zaradi preprostega vmesnika in rokovanja s podatki smo se odločili uporabiti programski paket *ORANGE* za klasifikacijo. Sistem Orange uporabljamo s konceptom vizualnega programiranja. Na platno (angl. canvas) smo povlekli gradnike (angl. widget) in jih povezali. V nadaljevanju sledi podroben opis.

Vse posnetke smo normalizirali v skladu z enačbo 4.1 iz podpoglavja normalizacija fonokardiogramskega signala. Sledeča koda je v jeziku Matlab.

```
%Pripravimo nicelni vektor  
S = zeros(length(X),1);  
%Pridobimo absolutni maksimalni koeficient vektorja  
Smax = max(abs(X));  
%Izracunamo v skladu z enacbo  
for i = 1:length(X)
```



```

    S(i) = X(i) / Smax;
end

```

Ko normaliziramo signale, jih razstavimo na koeficiente s 3-stopenjsko valčno dekompozicijo. Vsaka valčna funkcija pokriva določeno frekvenčno območje. V primeru, da razstavimo signal do zadnje stopnje, tako da je pokrito celotno frekvenčno območje signala, potem bomo pri rekonstrukciji dobili enak signal kot na začetku. V našem primeru naredimo le dekompozicijo do izbrane frekvence. S tem ne zajamemo visokofrekvenčnega šuma (oscilacij). Druga vrstica kode predstavlja rekonstrukcijo. Torej naredimo rekonstrukcijo le do izbrane stopnje, s tem dobimo signal brez visokofrekvenčnih oscilacij. Na dekompozicijo in takoj za tem rekonstrukcijo lahko gledamo kot filtriranje, le da to naredimo na svojevrsten način.

```

%Opravimo dekompozicijo s Coiflet 3 valckom
[C,L] = wavedec(S,3,'coif3');
%Opravimo rekonstrukcijo signala s detajlnimi
%in aproksimacijskimi koeficienti
A3 = wrcoef('a',C,L,'coif3',3);

```

Izračunali smo koeficiente Morletove valčne transformacije z vgrajeno funkcijo *cwt*. Dobljeni koeficienti so kompleksna števila. V nadaljevanju jih ločimo z dvema vgrajenima ukazoma.

```

coefs = cwt(A3,200,'cmor1-0.5');
%Ločimo koeficiente na realne in imaginarne
r = real(coefs);
im = imag(coefs);

```

Absolutne vrednosti dobljenih kompleksnih koeficientov sestavlja ovojnico signala [6].

```

signal = zeros(1, length(coefs));


```

```

for i = 1:length(coefs)
    signal(i) = sqrt(r(i)^2 + im(i)^2);
end

```


Slika 4.9 prikazuje ovojnico signala, kjer smo z adaptivnim dinamičnim algortimom, ki je opisan v poglavju metode digitalnega procesiranja signalov, določili začetke in konce kardialnega cikla. Ker želimo ločiti signale le po tem ali je prisoten šum ali ne, in nas zaradi samih posnetkov omejuje le na binarni klasifikacijski problem. Zato ni pomembno, kako določimo zaporedje izsekov celotnega posnetka.



Slika 4.15: Primer originalnega signala, sedaj označen s srčnimi toni

Nato smo izračunali MFCC značilke nad prvim kardialnim ciklom. Vrednosti smo zapisali v *tab* datoteko, torej v datoteko, ki ima vrednosti ločene s tabulatorji. Zadnji atribut datoteke je zapis, ki označuje, ali gre za fonokardiogram označen kot Normal ali Murmur. Zadnji atribut slednjih datotek označuje ciljni razred. Datoteko smo uporabili kot vhod v programskem paketu Orange. Kot smo omenili že v uvodu smo povezali gradnike, tako kot prikazuje slika 4.16. Na začetku na platno dodamo gradnik *File*, kateremu

kot vhod damo datoteko z izračunanimi značilkami in ciljnim razredom. Gradnik *File* smo povezali na gradnik *Data sampler*. V gradniku *Data sampler* smo izbrali opcijo naključno vzorčenje, ter razdelili množico na testno ter učno. Lahko bi izbrali kakšno drugo opcijo, kot je prečno preverjanje, vendar cilj naloge ni doseči najboljših rezultatov. Cilj je bil preveriti, ali dosegamo boljšo klasifikacijsko točnost, kot jo da večinski klasifikator. Več poudarka je v slednji diplomski na uporabi različnih metod pri povezavi v skupno celoto.



Slika 4.16: Povezava gradnikov v paketu Orange

Poglavje 5

Evalvacija rezultatov

Zaradi omejitev, ki jih podaja podatkovna množica, moramo v nadaljevanju upoštevati, da gre le za dvorazredni problem. To je sicer velika pomankljivost, saj ne moremo testnim instancam oziroma fonokardiogramom pripisati določene diagnoze. Po drugi strani pa nekaj pridobimo, saj lahko na podlagi podatkov izračunamo meri: senzitivnost in specifičnost. Grafično ju lahko prikažemo s pomočjo ROC krivulje, kar je tudi narejeno v naslednjem poglavju.

5.1 Mere za oceno uspešnosti ML

Klasifikacijska točnost je definirana kot 5.1. Tukaj je r število vseh pravilno klasificiranih instanc ali primerov, N pa število vseh primerov.

$$CA = \frac{r}{N} \quad (5.1)$$

V dvorazrednem ali binarnem klasifikacijskem problemu, kot je to v našem primeru, obstajajo naslednji kriteriji za ocenitev, kako dobro se odrežejo ML algoritmi:

- TP je število pravilno pozitivnih učnih primerov.
- TN je število pravilno negativno učnih primerov.

- FP je število napačno pozitivnih učnih primerov.
- FN je število napačno negativnih učnih primerov.
- Senzitivnost, ki je definirano kot:

$$Sens = \frac{TP}{TP + FN} \quad (5.2)$$


- Specifičnost, ki je definirano kot:

$$Spec = \frac{TN}{TN + FP} \quad (5.3)$$


5.2 Rezultati

Na začetku smo izračunali 13 melodičnih frekvenčnih kepralnih koeficientov nad prvim kardialnim ciklom. Izbrali smo število 13 zaradi splošne veljave na področju procesiranja govora. Zaradi nizke klasifikacije točnosti v primerjavi s pričakovano točnostjo večinskega klasifikatorja smo se odločili, da jih izračunamo več kot je to predvideno v procesiranju govora. Tako smo povečevali število značilk, dokler nismo dobili boljše točnosti nad podatki. Najboljšo točnost smo dobili z 200 značilkami, nad prvim kardialnim ciklom.

Ker je podatkovna baza označena samo z oznakami pozitiven ali negativen in nimamo podrobnih diagnoz, je slednji korak poenostavljen. Celotno množico smo razdelili na učno in testno. Učna množica vsebuje 70 odstotkov vseh primerov in testna 30 odstotkov vseh primerov. Koeficiente smo uporabili kot vhod ML algoritmom. Podatkovna množica ni uravnotežena, zato je pričakovana točnost večinskega klasifikatorja 0,721519. Rezultati niso najboljši, vendar ker je klasifikacijska točnost ML algoritmov večja od večinskega klasifikatorja, sklepamo, da smo se nekaj naučili. Najboljšo CA daje naivni Bayesov klasifikator, najmanjšo pa večnivojski perceptron.




Slika 5.1: 13 MFCC vrednosti označenega kot MURMUR (šum)




Slika 5.2: 13 MFCC vrednosti označenega kot NORMAL (normalni)

5.2.1 Rezultati nadzorovanega učenja z 13 MFCC

Rezultati klasifikacije s 13 MFCC značilk so slabi. Vsi klasifikatorji dosegajo komaj za procent ali manj boljšo klasifikacijo kot večinski klasifikator. Zato



Slika 5.3: 200 MFCC vrednosti označenega kot MURMUR (šum)




Slika 5.4: 200 MFCC vrednosti označenega kot NORMAL (normalni)


smo v nadaljevanju diplome povečevali število izračunanih značilk. Naslednje boljše rezultate smo dosegli z 200 značilkami, kar je opisano v naslednjem podpoglavju.

Klasifikator	Klasifikacijska točnost
Naivni Bayes	0,7594937
K-NN (K = 13)	0,6708861
Večnivojski perceptron	0,721519
SVM	0,7468354


Klasifikator	Senzitivnost	Specifičnost
Naivni Bayes	0,4090909	0,8947368
K-NN (K = 13)	0	0,9298245
Večnivojski perceptron	0,3181818	0,877193
SVM	0,909090	1




Slika 5.5: ROC krivulja za naivni Bayes



Slika 5.6: ROC krivulja za k-najbližjih sosedov



Slika 5.7: ROC krivulja za večnivojski perceptron




Slika 5.8: ROC krivulja za metodo podpornih vektorjev

5.2.2 Rezultati nadzorovanega učenja z 200 MFCC


Rezultati so bistveno boljši kot poskusi s 13 značilkami. Dosegli smo najboljšo klasifikacijsko točnost z Naivnim Bayesovim klasifikatorjem, vendar pri točnosti večinskega klasifikatorja 75,2 %. Če bi bila množica uravnotežena, bi dobili točnost slabšo kot v članku [6]. Presenetljive razlike med senzitivnostjo in specifičnostjo glede na ostale ML probleme ni. ML algoritem v nekaterih primerih zadane bolje pozitiven razred v drugih pa negativni razred.

Klasifikator	Klasifikacijska točnost
Naivni Bayes	0,9240506
K-NN (K = 13)	0,8860759
Večnivojski perceptron	0,835443
SVM	0,8860759


Klasifikator	Senzitivnost	Specifičnost
Naivni Bayes	0,7692308	0,9545455
K-NN (K = 13)	0,3076923	1
Večnivojski perceptron	0,6923077	0,8636364
SVM	0,3846154	0,9848485




Slika 5.9: ROC krivulja za naivni Bayes



Slika 5.10: ROC krivulja za k-najbližjih sosedov



Slika 5.11: ROC krivulja za večnivojski perceptron



Slika 5.12: ROC krivulja za metodo podpornih vektorjev

Poglavje 6

Zaključek in nadaljnje delo

V okviru diplomske naloge smo implementirali algoritme in pristope za avtomatsko iskanje srčnega šuma v fonokardiogramih. Namen dela je bil, da pregledamo vse možnosti ter dodatno nadgradimo obstoječe postopke, ki bi olajšali delo kardiologom oziroma začetnikom pri postavljanju bolj objektivne diagnoze bolezni srčnih zaklopk. Implementacijo smo izvedli v programskem jeziku *MATLAB*, ki je prav tako programsko razvojno okolje. Za izbiro *MATLAB* smo se odločili, zato ker ima veliko funkcij za obdelavo signalov že vgrajenih. Testiranje z uporabo algoritmov strojnega učenja smo izvedli v programskem paketu Orange.

V začetku dela smo predstavili generične koncepte in se seznanili z osnovnimi pojmi, ki se uporabljajo v kardiologiji ter na matematičnem področju obdelave signalov. Proti koncu pa smo se osredotočili na rezultate, ki jih dajejo algoritmi pognani nad našo podatkovno bazo. Ugotovili smo, da so problemi s področja analize signalov, kot so govorni oziroma v splošnem zvočni, kot je v našem primeru fonokardiogram, kompleksni. Diplomaska naloga trenutno predstavlja celovit pregled nad ozko specializiranim področju avtomatske obdelave fonokardiogramov. Po dolgem iskanju strokovnih člankov, ki se nanaša na avtomatiziran pristop k obdelavi, smo našli le enega [6]. V članku ni eksplicitno navedeno število MFCC značilk, ki so jih izračunali nad enim

kardialnim ciklom. Vendar se iz grafa razbere, da jih je približno 65 [6]. Na podobnem področju pri razpoznavi govora jih v splošnem izračunajo 13, ostale pa zavržejo. Mi smo poskusili na začetku s 13 koeficienti. Ker rezultati niso bili zadovoljivi, smo povečevali število koeficientov s korakom 15. Pri 200 izračunanih koeficientih smo dobili boljše rezultate, torej takšne da je bila klasifikacijska točnost večinskega klasifikatorja večja od neodvisne testne množice. Iz tega lahko sklepamo, da je zgrajeni ML model uporaben, ni pa nujno uspešen.

Če primerjamo rezultate z raziskovalci iz članka, [6] smo dobili slabše. Slabše rezultate lahko pripisujemo drugi podatkovni bazi, kjer posamezni fonokardiogrami vsebujejo nekaj šuma, ki je nastal v okolici. Vsi realni posnetki bodo imeli šum, zato bi morali v nadaljnjem delu poskušati nekako filtrirati šum, ki je nastal v okolici in ki ni posledica stanje pacienta. V digitalnem procesiranju signalov obstaja še veliko možnosti, kako bi signal obdelali. Vendar smo se v diplomski osredotočili le na določen pristop, saj je področje obdelave signalov bogato z različnimi metodami, ki se še razvijajo naprej.

V nadaljevanju tega dela, bi lahko uporabo le enega srčnega cikla, nadomestili z več zaporednimi. Na tako stvar lahko gledamo kot verigo, kjer vsak člen verige predstavlja delček izračuna verjetnosti diagnoze pacienta. V primeru, da imamo 10 zaporednih srčnih ciklov meritve, in samo na enem srčnem ciklu je prisoten šum na ostalih pa ni, pomeni, da je tudi zelo majhna verjetnost da ima pacient kakšno od diagnoz, ki smo jih predstavili v drugem poglavju (verjetno napaka pri avskultaciji).

Poglavje 7

Dodatek

V dodatku se nahaja dinamični adaptivni algoritem. Pripadajoča koda je napisana v MATLAB jeziku.

```
maksSeznam = [];  
visina = max(zSignal);  
smer = false;  
epsilon = 500  
  
while (true)  
    [pks,locs] = findpeaks(zSignal,'MinPeakDistance',  
        1000,'MinPeakHeight',visina);  
  
    celice = [];  
    large = [];  
  
    for i=1:length(locs)-1  
        celice = [celice, locs(i+1) - locs(i)];  
    end  
  
    for j=1:2:length(celice)-2  
        large = [large, abs(celice(j+2)-celice(j))<epsilon];
```

```
end

maksSeznam = [maksSeznam, sum(large)];

if (length(maksSeznam) > 2)
    p1 = maksSeznam(length(maksSeznam)-1);
    p2 = maksSeznam(length(maksSeznam)-2);
    if p2 > p1
        smer = true;
    else
        smer = false;
    end

if length(maksSeznam) > 200
    break;
end

end

if smer == true
    visina = visina + 0.1;
else
    visina = visina - 0.1;
end

[pks, locs] = findpeaks(zSignal, 'MinPeakDistance',
    ,1000, 'MinPeakHeight', visina);
cikel = zeros(1, 10);
try
    cikel = Y(locs(1):locs(3));
end
cikel
end
```

Literatura

- [1] L. Fortnow, "Viewpoint: Time for computer science to grow up", *Communications of the ACM*, št. 52, zv. 8, str. 33–35, 2009.
- [2] Andrew Tangborn, "Wavelet Transforms in Time Series Analysis"
- [3] Robi Polikar "The wavelet tutorial"
- [4] Steven W. Smith, Ph.D., The Scientist and Engineer's Guide to Digital Signal Processing
- [5] Igor Kononenko, Marko Robnik Šikonja "Inteligentni sistemi"
- [6] Lisha Zhong, Jiangzhong Wan, Zhiwei Huang*, Gaofei Cao, Bo Xiao, "Heart Murmur Recognition Based on Hidden Markov Model" 2013
- [7] Bentley, P. and Nordehn, G. and Coimbra, M. and Mannor, S., "The PASCAL Classifying Heart Sounds Challenge 2011 (CHSC2011) Results" dostopno na:
<http://www.peterjbentley.com/heartchallenge/index.html>
- [8] Dostopno na:
<http://en.wikipedia.org/wiki/Stethoscope> (2015)
- [9] Abbas K. Abbas, Rasha Bassam, "Phonocardiography Signal Processing"
- [10] Wiley, Signal Analysis - Wavelets, Filter banks, Time-frequency transforms and Applications

- [11] Dostopno na:
<http://www.analytictech.com/ba762/handouts/normalization.htm>
(2015)
- [12] Dostopno na:
http://www.saedsayad.com/naive_bayesian.htm (2015)
- [13] Dostopno na:
http://docs.opencv.org/doc/tutorials/ml/introduction_to_svm/introduction_to_svm.html
- [14] Dostopno na:
http://en.wikipedia.org/wiki/Heart_murmur (2015)
- [15] Dostopno na:
<http://www.usrschoolsk8.com/Reynolds/vanRiper/Documents/Forms/AllItems.aspx>
(2015)
- [16] Dostopno na:
<http://practicalcryptography.com/miscellaneous/machine-learning/guide-mel-frequency-cepstral-coefficients-mfccs/> (2015)
- [17] Jean-Philippe Vert, Support vector machines (SVM) in bioinformatics